# Algorithmes efficaces pour l'apprentissage de réseaux de préférences conditionnelles à partir de données bruitées

#### Fabien LABERNIA

Directeur : Jamal ATIF Co-encadrant : Brice MAYAG

Université Paris-Dauphine - LAMSADE

Jeudi 27 Septembre 2018









### Sommaire

- Préliminaires
  - Contexte
  - Préférences
  - CP-nets
  - Apprentissage de CP-nets
- Algorithme hors ligne
  - Principe général
  - Entropies
  - Gain d'information
  - Procédure globale

- Adaptation aux flux de données
  - Difficultés à relever
  - Compteurs
  - Estimation des compteurs
  - Borne de McDiarmid
  - Procédure globale
- Expérimentations
  - Protocole d'expérimentation
  - Données synthétiques
  - Données réelles
  - Comparaisons avec l'état de l'art
- 5 Conclusion et perspectives

Préliminaires
Algorithme hors ligne
Adaptation aux flux de données
Expérimentations
Conclusion et perspectives

ontexte références P-nets pprentissage de CP-nets

### **Préliminaires**

### Contexte





- Récupération et traitement des informations
- Création d'assistants personnels (Siri, Cortana, ...)
- Personnalisation en fonction des habitudes
- Recommandations de plus en plus ciblées

### Préférences



- Apparaissent à tous les niveaux (achats, sites Web, ...)
- Sont facilement déductibles (clics de souris, pages visitées, ...)
- Nécessitent des structures de représentation efficaces (stockage, propriétés, ...)

#### Question

Comment représenter certains types de préférences de façon simple, compacte, et interprétable?

# Préférences ceteris paribus

- « Dois-je acheter la voiture spacieuse avec boîte manuelle, ou bien le plus petit modèle avec boîte automatique? »
  - Réponse difficile car objets trop différents
  - Attribut = taille de la voiture, couleur, type de transmission, ...
  - Deux objets identiques excepté sur 1 attribut ⇒ choix plus facile
  - Notion ceteris paribus (« toutes choses étant égales par ailleurs »)
  - Swap : préférence entre une paire d'objets ceteris paribus

### Préférences conditionnelles

« Si je conduis seul, alors je vais préférer acheter une petite voiture. À l'inverse, si je conduis avec ma famille, alors que je vais privilégier un plus grand modèle. »

- Contexte = valeurs d'attributs
- Préférence conditionnelle = préférence dépendante d'un contexte
- Variable parente : variable dont les valeurs influencent les préférences liées à une autre variable

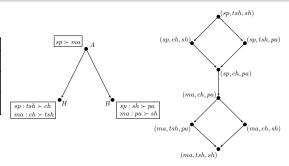
# Réseaux de préférences conditionnelles (CP-nets)

#### **CP-nets**

Formalisation des réseaux de préférences conditionnelles (CP-nets) par Boutilier *et al.* [BBD<sup>+</sup>04] basée sur :

- préférences ceteris paribus
- préférences conditionnelles

Variable	Valeurs
A : Activité	sp : sport ma : mariage
H : haut de vêtement	tsh : t-shirt ch : chemise
$\boldsymbol{B}$ : bas de vêtement	sh : short pa : pantalon



# Formulation du problème

- V un ensemble de n variables
- $Dom(V) = \{v, v'\}$  les valeurs possibles pour une variable  $V \in \mathbf{V}$
- ullet Soit  $Y_V=\{1_V,0_V\}$  un ensemble de classes tel que
  - Si  $s = (\mathbf{o}, \mathbf{o}')_V \Rightarrow v \succ v'$ , alors s est étiqueté  $1_V$
  - Si  $s = (\mathbf{o}, \mathbf{o}')_V \Rightarrow v' \succ v$ , alors s est étiqueté  $0_V$
- $S = \{(s_1, y_1), \dots, (s_m, y_m)\}$ , avec  $s_i = (\mathbf{o}, \mathbf{o}')_V^i$ , et  $y_i \in Y_V$
- Chaque  $s \in S$  est potentiellement bruité par  $p \in [0,1]$
- $h_S \in \mathcal{H}^k_{\mathsf{acv}}$  un CP-net appris
- Maximiser  $prec(S, h_S) = \frac{1}{|S|} \sum_{s \in S} \mathbb{1}(y_s = h_S(s)) \in [0, 1]$

#### Question

Comment apprendre, de manière efficace, et en présence de bruit, des réseaux de préférences conditionnelles acycliques?

# Apprentissage de CP-nets

#### Méthodes existantes

- Régression [EV09, EV10, LSD+16]
- Réduction vers 2-SAT [DMA09]
- Apprentissage de l'ordre partiel des objets [LYX<sup>+</sup>13, LXW<sup>+</sup>14]
- Apprentissage par requêtes [CKL+10, KZ10, GAG13]

#### Limites de la littérature

- Un seul algorithme en ligne [GAG13]
- Très peu d'algorithmes capables de gérer le bruit [LYX+13, LXW+14]
- Aucune expérience sur de larges jeux de données réelles

### Nos contributions

#### Première contribution

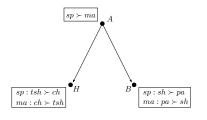
Algorithme d'apprentissage hors ligne en milieu bruité basé sur des requêtes

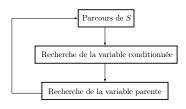
#### Deuxième contribution

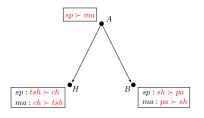
- Algorithme d'apprentissage hors ligne en milieu bruité basé sur une mesure d'entropie
- Algorithme d'apprentissage en ligne en milieu bruité basé sur une mesure d'entropie

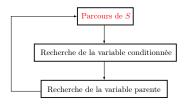
Principe general Entropies Gain d'information Procédure globale

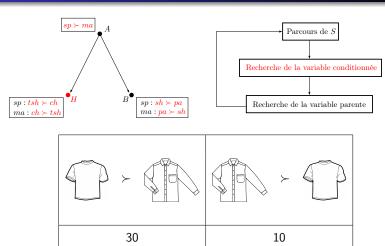
# Algorithme hors ligne

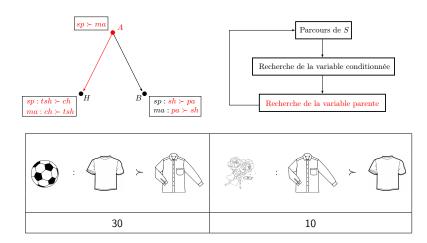












### Choix de la variable conditionnée

# Entropie d'une variable

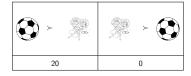
- V un ensemble de variables
- $V \in \mathbf{V}$  une variable
- $S_V = \{(s_1, y_1), \dots, ((s_l, y_l))\}$  un ensemble de couples
- Entropie de V associée à la classification des éléments de  $S_V$  :

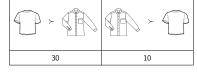
$$\hat{H}_{1/2}(S_V) = \sum_{(\mathbf{u}:\succ_{Dom(V)})\in CPT(V)} \frac{|S_V^{\mathbf{u}}|}{|S_V|} \hat{H}_{1/2}(S_V, (\mathbf{u}:\succ_{Dom(V)})),$$

avec

$$\hat{H}_{1/2}(S_V,(\mathbf{u}:\succ_{\mathit{Dom}(V)})) = -\sum_{y\in Y_V} \frac{|S_y^\mathbf{u}|}{2|S_V^\mathbf{u}|} \ln \frac{|S_y^\mathbf{u}|}{|S_V^\mathbf{u}|}$$

### Choix de la variable conditionnée



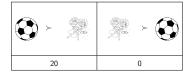


$$\hat{H}_{1/2}(S_A)=0$$

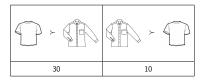
$$\hat{H}_{1/2}(S_H) = 0.281$$

$$\hat{H}_{1/2}(S_B) = 0.162$$

### Choix de la variable conditionnée



$$\hat{H}_{1/2}(S_A)=0$$



$$\hat{H}_{1/2}(S_H) = 0.281$$

$$\hat{H}_{1/2}(S_B) = 0.162$$

# Choix de la variable parente

#### Entropie d'un couple de variables

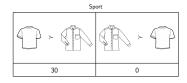
- V un ensemble de variable
- $V, Q \in \mathbf{V}$  deux variables tel que  $Q \in \overline{Pa}(V)$
- $S_V = \{(s_1, y_1), \dots, ((s_l, y_l))\}$  un ensemble de couples
- Entropie du couple de variables (Q, V) étant donné un ensemble  $S_V$  :

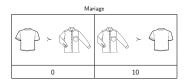
$$\hat{\mathcal{H}}_{1/2}(\mathcal{S}_V, \mathcal{Q}) = \sum_{q \in \mathit{Dom}(\mathcal{Q})} \sum_{(\mathbf{u}: \succ_{\mathit{Dom}(V)}) \in \mathit{CPT}(V)} \frac{|S_V^{\mathbf{uq}}|}{|S_V|} \hat{\mathcal{H}}_{1/2}(\mathcal{S}_V, (\mathbf{u}: \succ_{\mathit{Dom}(V)}), q),$$

avec

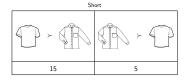
$$\hat{H}_{1/2}(S_V, (\mathbf{u} : \succ_{Dom(V)}), q) = -\sum_{y \in Y_V} \frac{|S_y^{\mathbf{u}q}|}{2|S_V^{\mathbf{u}q}|} \ln \frac{|S_y^{\mathbf{u}q}|}{|S_V^{\mathbf{u}q}|}$$

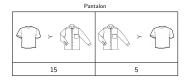
# Choix de la variable parente





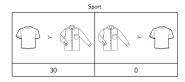
$$\hat{H}_{1/2}(S_H,A)=0$$

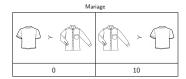




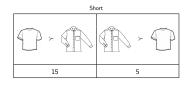
$$\hat{H}_{1/2}(S_H, B) = 0.281$$

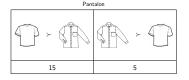
# Choix de la variable parente





$$\hat{H}_{1/2}(S_H,A)=0$$





$$\hat{H}_{1/2}(S_H, B) = 0.281$$

# Recherche de tous les couples potentiels

#### Gain d'information

- V un ensemble de variable
- $V, Q \in \mathbf{V}$  deux variables tel que  $Q \in \overline{Pa}(V)$
- $S_V = \{(s_1, y_1), ..., ((s_l, y_l))\}$  un ensemble de couples
- Gain d'information de la variable Q par rapport à la variable V, correspondant à la différence entre l'entropie de V avant l'ajout de la variable Q comme variable parente, et l'entropie de V après son ajout :

$$\hat{G}_{1/2}(S_V,Q) = \hat{H}_{1/2}(S_V) - \hat{H}_{1/2}(S_V,Q)$$

### Gain d'information

$$\hat{G}_{1/2}(S_A, H) = 0 - 0 = 0 
\hat{G}_{1/2}(S_A, B) = 0 - 0 = 0 
\hat{G}_{1/2}(S_H, A) = 0.281 - 0 = 0.281 
\hat{G}_{1/2}(S_H, B) = 0.281 - 0.281 = 0 
\hat{G}_{1/2}(S_B, A) = 0.162 - 0 = 0.162 
\hat{G}_{1/2}(S_B, H) = 0.162 - 0.162 = 0$$

### Gain d'information

$$\hat{G}_{1/2}(S_A, H) = 0 - 0 = 0$$

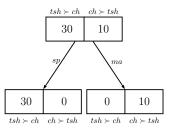
$$\hat{G}_{1/2}(S_A, B) = 0 - 0 = 0$$

$$\hat{G}_{1/2}(S_H, A) = 0.281 - 0 = 0.281$$

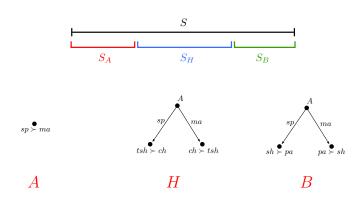
$$\hat{G}_{1/2}(S_H, B) = 0.281 - 0.281 = 0$$

$$\hat{G}_{1/2}(S_B, A) = 0.162 - 0 = 0.162$$

 $\hat{G}_{1/2}(S_B, H) = 0.162 - 0.162 = 0$ 

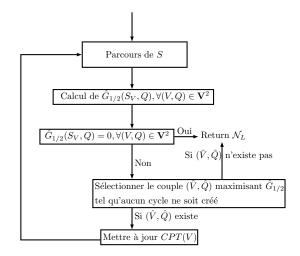


# Apprentissage de plusieurs arbres de décision



Soit  $\mathbf{V} = \{A, B, C\}$ , il est possible d'apprendre en simultané plusieurs arbres de décision

# Version hors ligne : procédure générale



Préliminaires
Algorithme hors ligne
Adaptation aux flux de données
Expérimentations
Conclusion et perspectives

ifficultes a relever ompteurs stimation des compteur: orne de McDiarmid rocédure globale

# Adaptation aux flux de données

### Difficultés à relever

#### Information limitée

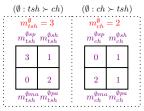
- Accès unique à chaque swap
- Comment gérer un flux de données
- Comment estimer l'information?

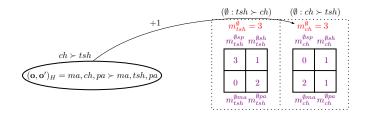
#### Prise de décision

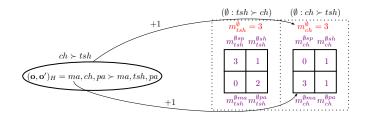
- À quel moment doit-on ajouter une variable parente?
- Comment distinguer le bruit d'un conditionnement?
- ⇒ Borne de McDiarmid

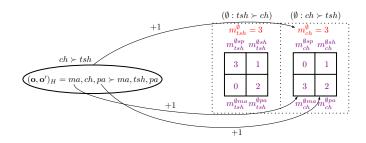
$$ch \succ tsh$$

$$(\mathbf{o}, \mathbf{o}')_H = ma, ch, pa \succ ma, tsh, pa)$$

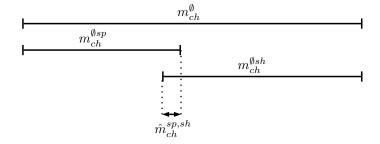








# Estimation des compteurs



Pour une nouvelle CP-règle fixée, estimation du compteur  $\hat{m}_{ch}^{sp,sh}$  ayant simultanément les valeurs sp et sh de la nouvelle variable parente A, et de la variable non parente B, respectivement

### Borne de McDiarmid

Soient  $V \in \mathbf{V}$  une variable,  $X \in \overline{Pa}(V)$  une variable non parente de V, et  $S_V^{(m_V)}$  un ensemble composé des  $m_V$  premiers swaps d'un ensemble  $S_V$  (les swaps sont tirés i.i.d). Considérons  $\hat{H}_{1/2}$  une entropie normalisée issue des  $m_V$  swaps, et  $\hat{G}_{1/2}\left(S_V^{(m_V)},Q\right) = \left|\hat{H}_{1/2}\left(S_V^{(m_V)}\right) - \hat{H}_{1/2}\left(S_V^{(m_V)},Q\right)\right|$ . Alors pour tout  $\delta \in (0,1]$ ,

$$\begin{split} \left| \hat{G}_{1/2} \left( S_V^{(m_V)}, Q \right) - G_{1/2} \left( S_V^{(m_V)}, Q \right) \right| &\leq \epsilon(m_V, \delta), \\ \text{où } \epsilon(m_V, \delta) &= \ln(m_V) \sqrt{\frac{2}{m_V} \ln \frac{4}{\delta}} + \frac{2}{m_V}, \end{split}$$

avec une probabilité d'au moins  $1-\delta$  sur l'ensemble des m swaps.

### Borne de McDiarmid

$$hatG_{1/2}\left(S_{H}^{(m_{H})},A\right) - \epsilon(m_{H},\delta) \quad \hat{G}_{1/2}\left(S_{H}^{(m_{H})},A\right) + \epsilon(m_{H},\delta) \\ \hat{G}_{1/2}\left(S_{B}^{(m_{B})},A\right) - \epsilon(m_{B},\delta) \quad \hat{G}_{1/2}\left(S_{B}^{(m_{B})},A\right) + \epsilon(m_{B},\delta) \\ \hat{G}_{1/2}\left(S_{B}^{(m_{B})},A\right) - \epsilon(m_{B},\delta) \quad \hat{G}_{1/2}\left(S_{B}^{(m_{B})},A\right) + \epsilon(m_{B},\delta)$$

Illustration de la borne de McDiarmid

# Hyperparamètres utilisés

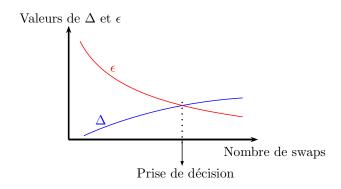


Illustration de l'influence des hyperparamètres sur la prise de décision

## Hyperparamètres utilisés

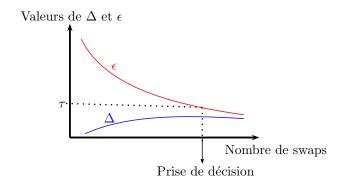


Illustration de l'influence des hyperparamètres sur la prise de décision

## Hyperparamètres utilisés

### Hyperparamètre $\delta$

- Hyperparamètre définissant un intervalle de confiance
- Permet de faire varier le nombre de swaps requis pour la prise de décision
- ullet Plus  $\delta$  est faible, plus la décision est considérée comme correcte

### Hyperparamètre au

- Hyperparamètre assurant une prise de décision
- Intervient dans le cas où il n'est pas possible de départager deux couples de variables qui évoluent parallèlement
- ullet Joue le rôle de « seuil » basé sur  $\epsilon$
- Permet une prise de décision dès qu'un nombre suffisant de swaps a été observé

## Correction automatique des estimations

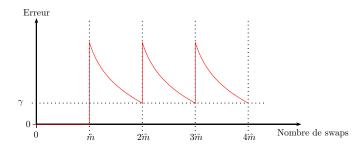
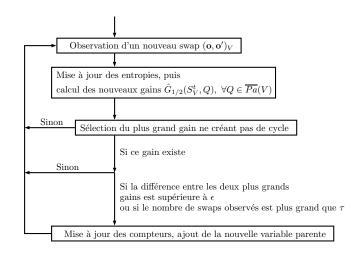


Illustration de l'erreur entre les compteurs estimés et les compteurs réels

# Version en ligne : procédure générale



otocole d'expérimentation onnées synthétiques onnées réelles omparaisons avec l'état de l'art

# Expérimentations

## Les différents jeux de données utilisés

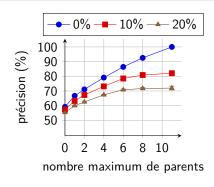
### Jeux de données synthétiques bruités

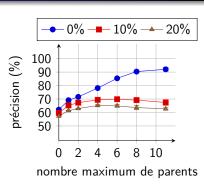
- $p \in [0, 1]$  : probabilité d'inverser une préférence (bruit)
- $S = \{ \mathbf{o}_i \succ \mathbf{o}_j \mid i, j \in \{1, \dots, m\} \}$  : base de données de swaps
- Construction de S:
  - **1** Génération aléatoire d'un CP-net  $\mathcal{N}_T$
  - ② Génération d'un swap dont la préférence est conforme à  $\mathcal{N}_{\mathcal{T}}$
  - Bruitage de ce swap suivant p
  - Recommencer l'étape 2

#### Précision utilisée

$$prec(S, h_S) = \frac{1}{|S|} \sum_{s \in S} \mathbb{1}(y_s = h_S(s)) \in [0, 1]$$

## Efficacité de l'apprentissage en milieu bruité

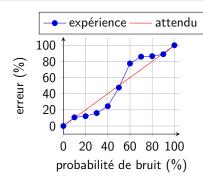


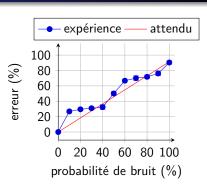


- Hors ligne
- 200 000 swaps
- 12 variables

- En ligne
- 1 500 000 swaps
- 12 variables

## Résistance au bruit : résultats

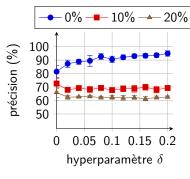


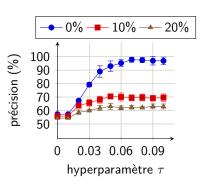


- Hors ligne
- 200 000 swaps
- 12 variables

- En ligne
- 1 500 000 swaps
- 12 variables

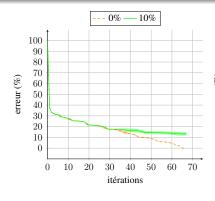
## Influence des hyperparamètres

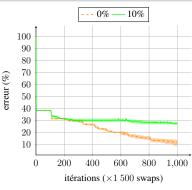




- 1 500 000 swaps
- 12 variables

## Convergence empirique

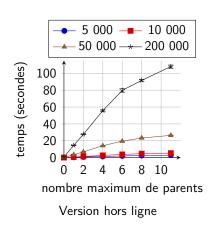


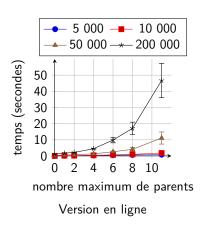


- Hors ligne
- 200 000 swaps
- 12 variables

- En ligne
- 1 500 000 swaps
- 12 variables

## Temps de calcul





## Données réelles

#### Bases de données

- TripAdvisor
  - 240 000 reviews notées de 0 à 5
  - 7 variables à binariser (notes de catégories entre 0 et 5)
- SUSHI
  - 100 sushis classés (ordre total) par 5 000 utilisateurs
  - 3 variables à binariser
- MovieLens
  - 2 000 000 films notés de 0 à 5
  - 19 variables binaires

### Résultats préliminaires

- Précision moyenne : 60%
- Aucune évolution en fonction des variables parentes
- Explication possible : pas de conditionnements

## Comparaison avec l'état de l'art

### Algorithme de Liu *et al.* [LXW<sup>+</sup>14]

- Algorithme hors ligne
- Prend en compte le bruit
- Apprentissage basé sur l'ordre partiel des objets
- Complexité temporelle élevée
- Limité à peu de variables

### Algorithme de Guerin et al. [GAG13]

- Algorithme en ligne
- Sans prise en compte du bruit
- Apprentissage par sous-ensembles de variables parentes

# Algorithme de Liu et al. [LXW<sup>+</sup>14]

Bruit (%)	Liu et al. [LXW+14] (%)	Version hors ligne (%)	Version en ligne (%)	
500 swaps				
0	100	100	83	
1	99	98	83	
5	95	94	80	
10	91	89	77	
20	81	79	70	
40	68	60	57	
1 000 swaps				
0	100	100	82	
1	99	98	81	
5	95	94	79	
10	90	89	75	
20	80	80	69	
40	60	60	57	

Résultats d'apprentissage entre les versions hors ligne, en ligne, et l'algorithme de  $[LXW^+14]$ 

# Algorithme de Guerin et al. [GAG13]

	D ( :: (0/)	F (0/)	1 1/ (0/)		
n	Précision (%)	Erreur (%)	Indécision (%)		
$\lambda = 3$					
4	98	2	0		
	94	6	0		
8	80	4	16		
	98	2	0		
12	62	4	34		
	99	1	0		
$\lambda = \frac{n-1}{2}$ 98 2 0					
4	98	2	0		
	92	8	0		
8	76	2	22		
	99	1	0		
12	54	4	42		
	98	2	0		

Résultats d'apprentissage entre la version en ligne (cellules grises) et l'algorithme de [GAG13] (cellules blanches), sur 1 500 000 comparaisons

Préliminaires
Algorithme hors ligne
Adaptation aux flux de donnés
Expérimentations
Conclusion et perspectives

## Conclusion et perspectives

## Conclusion et perspectives

#### Travail réalisé

- Algorithmes inspirés des apprentissages d'arbres de décision
- Adaptation en ligne
- Bonne résistance aux préférences bruitées
- Résultats d'apprentissage encourageants

### Perspectives

- Prouver théoriquement la convergence du modèle appris
- Suppression de variables parentes
- Algorithmes d'apprentissage sur les extensions des CP-nets (TCP-nets, ...)

### Some references I



Craig Boutilier, Ronen I. Brafman, Carmel Domshlak, Holger H. Hoos, and David Poole.

Cp-nets: A tool for representing and reasoning with conditional ceteris paribus preference statements. Journal of Artificial Intelligence Research, 21:135–191, 2004.



Yann Chevaleyre, Frédéric Koriche, Jérôme Lang, Jérôme Mengin, and Bruno Zanuttini.

Learning ordinal preferences on multiattribute domains: The case of cp-nets. In *Preference Learning*., pages 273–296. Springer, 2010.



Yannis Dimopoulos, Loizos Michael, and Fani Athienitou.

Ceteris paribus preference elicitation with predictive guarantees.

In IJCAI 2009, Proceedings of the 21st International Joint Conference on Artificial Intelligence, Pasadena, California, USA, July 11-17, 2009, pages 1890–1895, 2009.



Alan Eckhardt and Peter Vojtás.

How to learn fuzzy user preferences with variable objectives.

In Proceedings of the Joint 2009 International Fuzzy Systems Association World Congress and 2009 European Society of Fuzzy Logic and Technology Conference, Lisbon, Portugal, July 20-24, 2009, pages 938–943, 2009.



Alan Eckhardt and Peter Vojtás.

Learning user preferences for 2cp-regression for a recommender system.

In SOFSEM 2010: Theory and Practice of Computer Science, 36th Conference on Current Trends in Theory and Practice of Computer Science, Spindleruv Mlýn, Czech Republic, January 23-29, 2010. Proceedings, pages 346–357, 2010.



Joshua T. Guerin, Thomas E. Allen, and Judy Goldsmith.

Learning cp-net preferences online from user queries.

In Late-Breaking Developments in the Field of Artificial Intelligence, Bellevue, Washington, USA, July 14-18, 2013, 2013.



Joseph L Gastwirth.

The estimation of the lorenz curve and gini index.

The Review of Economics and Statistics, pages 306-316, 1972.



Wassily Hoeffding

Probability inequalities for sums of bounded random variables.

Journal of the American statistical association, 58(301):13-30, 1963,

### Some references II



Frédéric Koriche and Bruno Zanuttini.

Learning conditional preference networks.

Artificial Intelligence, 174(11):685-703, 2010.



Juntao Liu, Chenhong Sui, Dewei Deng, Junwei Wang, Bin Feng, Wenyu Liu, and Caihua Wu.

Representing conditional preference by boosted regression trees for recommendation.

Information Sciences, 327:1-20, 2016.



Juntao Liu, Yi Xiong, Caihua Wu, Zhijun Yao, and Wenyu Liu.

Learning conditional preference networks from inconsistent examples.

IEEE Transactions on Knowledge and Data Engineering, 26(2):376–390, 2014.



Juntao Liu, Zhijun Yao, Yi Xiong, Wenyu Liu, and Caihua Wu.

Learning conditional preference network from noisy samples using hypothesis testing.

Knowledge-Based Systems, 40:7-16, 2013.



Sergei A. Obiedkov.

Modeling ceteris paribus preferences in formal concept analysis.

In Formal Concept Analysis, 11th International Conference, ICFCA 2013, Dresden, Germany, May 21-24, 2013. Proceedings, pages 188–202, 2013.